

COMPARISON OF DATA FROM SMARTPHONES AND SPECIALISED DEVICES

Diana Kačníková

Bachelor Degree Programme (3), FEEC BUT

E-mail: xkacni00@stud.feec.vutbr.cz

Andrea Němcová

E-mail: nemcovaa@feec.vutbr.cz

Abstract: The aim of this study is to introduce two algorithms for physical activity recognition and to compare various devices such as smartphones and specialized devices using these algorithms. Signals are recorded using smartphones and accelerometer Axivity AX3. In the first part of the report, classification algorithms are described. In the second part algorithms are tested using recorded signals and the last part provides comparison of above mentioned tested devices.

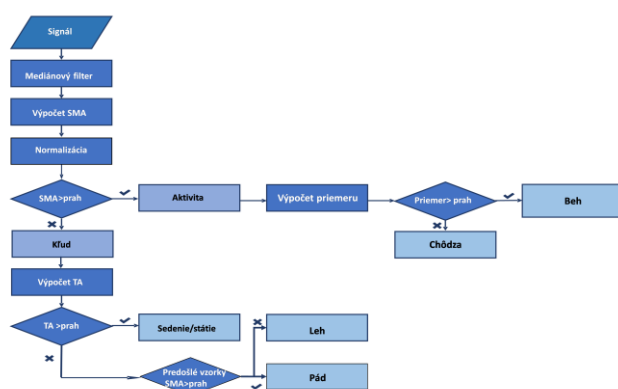
Keywords: Accelerometer, Axivity AX3, fall detection, physical activity, step counter, smartphone, pedometer

1 ÚVOD

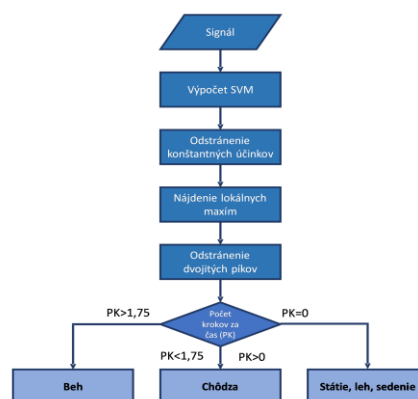
Rozpoznanie ľudskej činnosti z nositeľných zariadení je sľubné pre zdravotnú starostlivosť, vyhodnotenie športových výkonov a ohodnotenie životného štýlu. Najväčšou motiváciou je detekcia pádu, kedy pád je v skutočnosti jedným z najčastejších úrazov, ktoré vedú ku bolesti, invalidite alebo dokonca až smrti. Ďalším cieľom je detekcia konkrétnej aktivity a počtu krokov. Zaznamenávanie signálov prebieha prostredníctvom senzorov, predovšetkým akcelerometru. Medzi faktory snímania patrí umiestnenie snímacieho zariadenia a typ snímacieho zariadenia. Snímacie zariadenie môže byť špecializované zariadenie – akcelerometer (napr. Axivity AX3) alebo je možné využiť chytrý telefón, ktorý sníma dáta prostredníctvom aplikácií.

2 ALGORITMY PRE HODNOTENIE AKTIVITY

V tejto kapitole sú popísané dva algoritmy. Obidva algoritmy do istej miery stanovujú rovnaké aktivity (beh, chôdza, státie/leh/sedenie) avšak každý algoritmus je založený na inom princípe a je schopný detekovať o niečo viac.



Obrázok 1: Algoritmus pre detekciu chôdze, behu, sedenia/státia, lehu a pádu



Obrázok 2: Algoritmus krokomeru

2.1 ALGORITMUS PRE DETEKCIU CHÔDZE, BEHU, SEDENIA/STÁTIA, LEHU A PÁDU

V programe Matlab R2017b bol vytvorený algoritmus pre detekciu aktivít, bloková schéma tohto algoritmu je zobrazená na obrázku 1.

Z akcelerometru špecializovaného zariadenia dostaneme x , y a z osy (všetky nasnímané signály boli snímané s $f_{vz} = 50$ Hz). Prvým krokom v algoritme je redukcia náhodného šumu pri súčasnom zachovaní hrán. Pre tento účel sa vykonala mediánová filtrácia s veľkosťou okna $n = 3$ vzorky. Po počiatocnej filtrácii signálu nasleduje výpočet SMA (Signal Magnitude Area) (1).

$$SMA(w) = \frac{1}{w} (\sum_{i=1}^w |x_i| + \sum_{i=1}^w |y_i| + \sum_{i=1}^w |z_i|) \quad (1)$$

kde x_i , y_i a z_i reprezentuje i -tá vzorka signálu os x , y , z v zvolenom okne o dĺžke w . Vďaka tomuto výpočtu je možné rozlíšiť časové úseky odpočinku a aktivity [1], [2].

Vzhľadom na to, že signál z Axivity AX3 má iný rozsah hodnôt ako chytrý telefón je potrebná normalizácia dát. Po tejto normalizácii je možné empiricky stanoviť jednu hodnotu prahu, vďaka ktorej je možné rozhodnúť či sa jedná o aktivitu alebo klúd. Prípad kedy hodnota SMA presahuje prah sa hodnotí ako chôdza/beh. Rozlíšenie týchto aktivít sa vykonáva prostredníctvom priemeru. Pokiaľ hodnota SMA nepresahuje stanovený prah je predpokladané, že osoba buď nevykonáva aktivitu teda je v klude alebo osoba padla. Pokiaľ je osoba v klude klasifikujeme jej aktivitu ďalej na sed, leh, pád alebo státie. Pre rozpoznanie týchto aktivít sa použil výpočet uhlu sklonu TA (Tilt Angle) (2) [1].

$$TA(i) = \arcsin \left(\frac{y_i}{\sqrt{x_i^2 + y_i^2 + z_i^2}} \right) \quad (2)$$

Výsledok TA sa prevedie do stupňov a pokiaľ je hodnota TA pod 40° hodnotí sa klúd ako leh/pád, pokiaľ je hodnota TA vyššia ako prah hodnotí sa aktivita ako sedenie/státie.

Pre detekciu pádu je vytvorená podmienka. Táto podmienka sa vzťahuje na 150 predošlých vzoriek SMA (3 sekundy záznamu). Pokiaľ tieto vzorky presahujú prah SMA a po nich nasleduje leh snímanej osoby, detekuje sa pád.

2.2 KROKOMER

Výstupom z krokometru je obvykle počet krokov. Ideálnym umiestnením špecializovaného zariadenia je na členku poprípadne na stehennom svale. Schéma navrhnutého algoritmu je zobrazené na obrázku 2.

Prvým krokom hodnotiaceho algoritmu je načítanie surových dát (3 osy akcelerometru telefónu / Axivity AX3). Tieto dáta sa spoja v jeden vektor a to na základe výpočtu SVM (Signal Magnitude Vector) (3) [2].

$$SVM(i) = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad (3)$$

Izolícia nie je nulová, preto sa vykoná odčítanie konkrétnej hodnoty zrýchlenia, v ktorej akcelerometer meria (napr. gravitačného). [3]. Následne sa nájdu lokálne maximá. Je potrebné stanoviť hodnotu minimálnej výšky píku - smerodajná odchýlka zo SVM. Len hodnoty nad týmto prahom sa budú považovať za krok. Pomocou dodatočnej úpravy je možné zredukovať detekovanie druhého chybného píku.

3 VÝSLEDKY

Na obrázku 3 je zobrazený signál číslo 1 nasnímaný prostredníctvom akcelerometru Axivity AX3, ktorý je vyhodnotený pomocou prvého navrhnutého algoritmu. Tabuľka 1 a 2 zobrazujú presnosť detekcie konkrétnych aktivít v percentách. Signál 1, 2, 4 a 5 sú nasnímané Axivity AX3, zatiaľ čo


signály 3, 6 a 7 chytrým telefónom Huawei P8 lite (aplikácia Sense it). Jedná sa len o odhad chýb a to z dôvodu, že nie je presne určené ohraňenie danej aktivity (nevie sa konkrétna hodnota vzorky, kedy sa vykonávanie danej aktivity začalo a ukončilo). Avšak pohľadom na nasnímaný signál je jednoduché začiatok a koniec aktivity odhadnúť a tento odhad porovnať s výsledkom detekcie. Referencie sú stanovené ručne a zobrazené formou čiary v grafe. V signále číslo 3 sa nenachádzala aktivita státie a preto nebola hodnotená presnosť tejto aktivity.

Aktivita	Beh	Chôdza	Státie	Ležanie	Pád
Sig. 1 [%]	99,62	98,22	60,43	99,54	100,00
Sig. 2 [%]	92,87	96,75	99,20	98,90	100,00
Sig. 3 [%]	94,65	94,21	XXX	97,73	100,00

Tabuľka 1: Algoritmus pre detekciu chôdze, behu, sedenia/státia, lehu a pádu

Aktivita	Beh	Chôdza	Státie	Kroky
Sig. 4 [%]	95,66	96,04	93,15	97,25
Sig. 5 [%]	93,79	95,97	98,17	99,00
Sig. 6 [%]	93,97	94,49	97,41	97,00
Sig. 7 [%]	92,10	96,55	98,31	100,00

Tabuľka 2: Algoritmus krokomeru



Obrázok 3: Výsledok algoritmu pre detekciu

chôdze, behu, sedenia/státia, lehu a pádu

4 DISKUSIA A ZÁVER

Ako je z kapitoly výsledky viditeľné presnosť detekcie sa nachádza v rozmedzí 90-100 %, s výnimkou státia v signále 1. Tieto výsledky sa považujú za uspokojivé. Vzorkovacia frekvencia a umiestnenie snímacieho zariadenia sa pokladajú za hlavné faktory, ktoré ovplyvňujú snímanie a presnosť detekcie. Prípadné nepresnosti môžu byť spôsobené výberom veľkosti okna w pri detekcii, artefaktami vzniknutými pri snímaní alebo nekonštantnou rýchlosťou vo vykonávaní aktivity. Ako veľký úspech sa pokladá detekcia pádu, ktorá je v signáloch 1, 2 a 3 nadetekovaná s presnosťou 100 %. Z Algoritmu pre detekciu chôdze, behu, sedenia/státia, lehu a pádu je viditeľné, že presnejšia detekcia aktivít je prostredníctvom Axivity AX3. Pri algoritme krokomeru sa presnosť detekcie pomocou telefónu a Axivity AX3 vyrovnáva.

REFERENCIE

- [1] HE, Y., Y. LI a S.-D. BAO. Fall Detection by Built-In Tri-Accelerometer of Smartphone. In: *International Conference on Biomedical and Health Informatics*. Hong-Kong, China: IEEE, 2012, s. 184-187. DOI: 10.1109/BHI.2012.6211540.
- [2] KARANTONIS D. M., M. R. NARAYANAN, M. MATHIE, N. H. LOVELL a B. G. CELLER. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE Transactions on Information Technology in Biomedicine*. 2006, 10(1), s. 156-167. DOI: 10.1109/TITB.2005.856864.
- [3] BYLEMANS, I., M. WEYN a M. KLEPAL. Mobile Phone-Based Displacement Estimation for Opportunistic Localisation Systems. In: *2009 Third International Conference on Mobile Ubiquitous Computing, Systems, Services and Technologies*. Sliema, Malta: IEEE, 2009, s. 113-118. DOI: 10.1109/UBICOMM.2009.23